



19 BUNDESREPUBLIK  
DEUTSCHLAND



DEUTSCHES  
PATENT- UND  
MARKENAMT

12 Offenlegungsschrift  
10 DE 197 43 600 A 1

51 Int. Cl.<sup>6</sup>  
G 07 C 3/14  
G 05 B 13/02  
G 01 C 3/00

21 Aktenzeichen: 197 43 600.5  
22 Anmeldetag: 2. 10. 97  
43 Offenlegungstag: 15. 4. 99

DE 197 43 600 A 1

71 Anmelder:  
Fraunhofer-Gesellschaft zur Förderung der  
angewandten Forschung eV, 80636 München, DE  
74 Vertreter:  
Dreiss, Fuhlendorf, Steimle & Becker, 70188  
Stuttgart

72 Erfinder:  
Schmidberger, Ernst, Dipl.-Ing., 70569 Stuttgart,  
DE; Schmutz, Manfred, Dr.rer.nat., 70569 Stuttgart,  
DE; Pannekamp, Jens, Dipl.-Ing., 70197 Stuttgart,  
DE

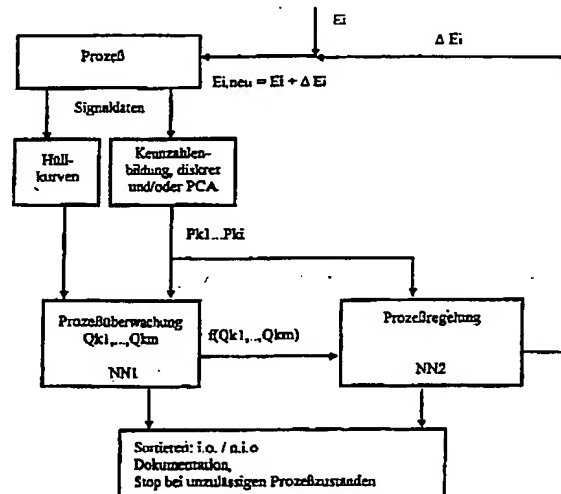
56 Entgegenhaltungen:  
DE 1 95 18 804 A1  
EP 00 84 284 A2  
Keek, Roland: Meßtechnik als Basis für "Total  
Quality Management" in der  
Prozeßautomatisierung,  
In: atp 1/95, S. S5-S8;

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen

Prüfungsantrag gem. § 44 PatG ist gestellt

54 Verfahren zur Überwachung eines zyklischen Produktionsprozesses

57 Es wird ein Verfahren zur Überwachung eines Produktionsprozesses beschrieben, bei dem Signalverläufe an mehreren Stellen des Produktionsprozesses aufgenommen werden und mindestens eine Qualitätsaussage zu den erzeugten Produkten abgeleitet wird. Das Verfahren weist unter anderem folgende Schritte auf:  
c) in einer Bewartungsphase werden die bei der Erzeugung der Produkte auftretenden Prozeßkennzahlen den zugehörigen Qualitätsmerkmalen der erzeugten Produkte zugeordnet,  
d) die derart gewonnenen Prozeßkennzahlen werden einem neuronalen Netzwerk als dessen Eingangsgrößen zugeführt,  
e) in einer Trainingsphase wird das neuronale Netzwerk derart trainiert, daß es mit hoher Sicherheit den bei einem späteren Prozeßabschnitt erzeugten Prozeßkennzahlen Qualitätsmerkmale zuordnet, die gleich denen des in dem Prozeßabschnitt erzeugten Produktes sind, und  
f) in einer Überwachungsphase werden aus den Prozeßkennzahlen mit Hilfe des trainierten neuronalen Netzwerks Qualitätsmerkmale und -klassen abgeleitet, die angezeigt und/oder dokumentiert und/oder zum Sortieren der erzeugten Produkte (i. o. oder n. i. o.) und/oder zur Regelung des Produktionsprozesses eingesetzt werden.



DE 197 43 600 A 1

## Beschreibung

Die Erfindung betrifft ein Verfahren zur Überwachung eines Produktionsprozesses, bei dem Signalverläufe an mehreren Stellen des Produktionsprozesses aufgenommen werden und mindestens eine Qualitätsaussage zu den erzeugten Produkten abgeleitet wird. Insbesondere betrifft die Erfindung ein Verfahren zur Überwachung eines zyklischen Produktionsprozesses, bei dem eine Erfassung von Signalverläufen mehrerer Zustandsgrößen des Prozesses durch Sensoren, eine Prüfung dieser Signale auf Zulässigkeit und, anhand aus den Signalverläufen erzeugter Prozeßkennzahlen, eine Prognose der Qualität der erzeugten Produkte stattfindet, die bei unerlaubter Ausprägung über eine Nachregelung der Einstellgrößen des Prozesses wieder in den erlaubten Bereich zurückgeführt wird.

Eine Produktionsüberwachung z. B. mit Hilfe der statistischen Prozeßregelung (SPC) basiert heute im wesentlichen auf einer Stichprobenförmigen Produktprüfung der fertigen Produkte. Die Nachprüfung der Produkte, sei es ständig, sei sie nur in Form von Stichproben, ist sehr aufwendig. Außerdem liegen die Prüfergebnisse größtenteils nur mit starkem Zeitverzug zur Herstellung vor. Eine qualitätsbezogene Regelung eines Prozesses durch Änderung der Einstellwerte ist jedoch nur mit sofortigem Wissen der Qualitätsmerkmale und der daraus abgeleiteten Werteänderung möglich. Wegen der komplexen Zusammenhänge zwischen Qualitätsabweichungen und den erforderlichen Einstellungsänderungen ist dies sehr schwierig und erfolgt deshalb häufig intuitiv oder heuristisch, also ohne fest zuordenbare Regeln, so daß sich dieses Wissen bzw. diese Regeln nicht oder nur unzureichend für eine Automatisierung eignen.

Aus der DE 42 09 746 A1 ist ein Verfahren zur Optimierung eines technischen Neuro-Fuzzy-Systems bekannt geworden, bei dem die Daten, mit denen der Neuro-Fuzzy-Regler trainiert wird, durch Simulation erzeugt werden. Diese Simulation ist aber ein aufwendiger Vorgang und setzt auch eine Kenntnis des Kausalzusammenhangs zwischen Prozeßablauf und den zum Training des Neuro-Fuzzy-Reglers erforderlichen Daten voraus.

Aus der DE 44 16 317 A1 ist ein Verfahren und eine Regeleinrichtung zur Regelung eines materialverarbeitenden Prozesses bekannt geworden, bei dem unter Berücksichtigung prozeßrelevanter Materialeigenschaften gewisse Prozeßparameter vorausberechnet werden, die zur Voreinstellung des Systems dienen. Auch diese Berechnung setzt die Kenntnis kausaler Zusammenhänge zwischen den auf den Prozeß einwirkenden Einflußgrößen und den Prozeßparametern voraus. Dies ist aber bei vielen Prozessen nicht möglich.

Dasselbe gilt auch für das Verfahren und die Regeleinrichtung nach der DE 44 16 364 A1.

Aufgabe der Erfindung ist es, ein Verfahren der genannten Art zu schaffen, das eine automatische Herstellung bei gleichbleibend hoher Qualität der erzeugten Produkte ermöglicht. Insbesondere soll eine automatische Überwachung des Produktionsprozesses, die zugehörige Dokumentation und eine qualitätsbasierte Regelung ohne Überprüfung der Produkte selbst nach deren Herstellung möglich sein.

Um dieses komplexe Verfahren mit der erforderlichen Einsatzsicherheit auszugestalten, erfolgt eine vorgelagerte Überprüfung der zugrundeliegenden Signaldaten auf Zulässigkeit in deren Ausprägung.

Die erfindungsgemäße Lösung der gestellten Aufgabe überwindet die Schwierigkeit, daß der Kausalzusammenhang zwischen Einstellgrößen des Prozesses, den Prozeßparametern, den Qualitätsmerkmalen und/oder den Merkmalsklassen der erzeugten Produkte nicht bekannt ist, und daß

die für einen Prozeß charakteristischen Daten eine Datenfülle ergeben, die parallel zum Prozeßablauf bisher nicht erfassbar und verarbeitbar war.

Zur Erläuterung sei noch folgendes ergänzt: Ein variables Qualitätsmerkmal ist z. B. die Länge eines Produktes, zum Beispiel 10,4 mm  $\pm 0,05$  mm, die als Wert zu erfassen, prognostizieren oder zu beurteilen ist. Von attributiven Qualitätsmerkmalen spricht man, wenn das zu klassifizierende Merkmal einer von mehreren Merkmalsklassen zugeordnet wird. Attributiv sind somit zu einer Teilebeurteilung mindestens zwei Merkmalsklassen (z. B. i.o. oder n.i.o.) erforderlich. Es können aber auch mehrere attributive Klassen sein, z. B. Klasse 1 = 10–11 mm, Klasse 2 = 11–12 mm, ..., Klasse x = 19–20 mm, oder, als benannte Klassen, zu wenig, untere Grenze, gut, obere Grenze, zu viel, usw. Diese Qualitätsmerkmale sind aus der in den Signalen enthaltenen Information über Prozeß- und somit auch Qualitätsschwankungen zu prognostizieren.

Aus dem US Patent 5,282,261 und der internationalen Patentanmeldung WO 93/25943 sind Verfahren zur Regelung von Prozessen bekannt, die aufbauen auf der Anwendung trainierbarer neuronaler Netze zur Vorhersage von Produkteigenschaften anhand direkter Erfassung und Eingabe von Prozeßzustandsmeßdaten bzw. anhand kombinierter Eingabe von Prozeßzustandsmeßdaten und aktuellen Werten der Prozeßstellgrößen. Die Eingabegrößen des neuronalen Netzes beziehen sich bei den zitierten Schriften jeweils auf einen bestimmten, äquidistanten Überwachungszeitpunkt eines kontinuierlichen Prozesses. Diese Vorgehensweise der Verwendung von Meßdatensätzen als Eingabe des Prädiktionssnetzes ist auf zyklische Prozesse in der Regel nicht übertragbar, da dann das neuronale Netz eine der Meßdatenzahl der Gesamtheit der beobachteten Signalverläufe entsprechende, außerordentlich große Zahl (typischerweise mehrere Tausend) von Inputneuronen und eine entsprechend große Zahl von durch ein Training zu bestimmende gewichtete Verbindungen zwischen den Neuronen haben müßte.

Da die für ein Training derartiger Netze notwendige, entsprechend große Anzahl von Muster- bzw. Versuchsdatensätzen nicht unter realen Bedingungen wegen des immensen Aufwandes erzeugbar sind, ist eine prozeßangepaßte Extraktion von Prozeßkenngrößen und eine darauf aufbauende, indirekte Prozeßmodellierung anhand eines minimierten Datensatzes von Prozeßkenngrößen somit bei zyklischen Prozessen, mit in der Regel geforderter kurzer Systemreaktionszeit, eine zwingende Voraussetzung.

In der Offenlegungsschrift DE 195 18 804 A1 sind Methoden zur diskreten Kennzahlenbildung beschrieben, wie Maximumbestimmung, Integrale, Gradienten etc., wie sie auch eingeschränkt in der vorliegenden Erfindung nutzbar sind.

Weiter sind ähnliche Ansätze bei den Prognosemodellen mit neuronalen Netzen feststellbar. Entscheidend ist, daß bei allen bekannten Schriften keine schlüssige Plausibilitätsprüfung der einbezogenen Signalquellen aufgeführt ist. Zudem erfolgt die Kennzahlenerzeugung vorwiegend durch anwenderbezogene, mathematische Algorithmen, die selbstredend nur einen beschränkten Teil der den Signalverläufen zugrundeliegenden Information über die Prozeßschwankungen repräsentieren.

Mit der hier dargestellten Lösung werden zum einen unerlaubte Signalformen, z. B. Sensordefekte oder Überschreiten der Prozeßgrenzen durch unterschiedliche Formen der Müllkurventechnik erkannt. Zudem wird mit der zugrundeliegenden Signalcodierung durch die Kombination von diskreter mathematischer Kenngrößenbestimmung und/oder Bestimmung dieser Kenngrößen durch die PCA-Kodierung (Principal Component Analysis) erst eine leistungsfähige

und aussagekräftige Kenngrößenbildung möglich. Die hier dargestellte Plausibilitätsprüfung der einbezogenen Signalquellen und die Art der Kennzahlenermittlung sind wesentliche Eigenschaften, die erst ein sicheres Arbeiten von Prognose- und Regelungsmodellen vor allem bei zyklischen Produktionsprozessen ermöglicht. Dies gilt auch für die hier dargestellte Modellierung mit neuronalen Netzen.

Erfindungsgemäß wird die genannte Aufgabe durch das Verfahren nach dem Patentanspruch 1 gelöst.

Insbesondere wird die Aufgabe dadurch gelöst, daß Signalverläufe von mehreren Zustandsgrößen des Prozesses während eines für die Erzeugung eines Produktes maßgeblichen Prozeßabschnittes mittels adaptiver Hüllkurven auf zulässige Ausprägung untersucht werden. Diese Hüllkurven werden anhand von Signalverläufen aus einer Versuchsreihe mit unterschiedlichen Prozeßeinstellungen und -zuständen, z. B. geänderter Maschineneinstellung anhand eines Versuchsplanes selbstadaptierend erzeugt. Aus zulässigen Signalverläufen der Meßdatenzeitreihen von mehreren, den Prozeßzustand erfassenden Sensoren werden während eines für die Erzeugung eines Produktes maßgeblichen Prozeßabschnittes eines zyklischen Produktionsprozesses Prozeßkennzahlen ermittelt.

Die Ermittlung dieser Prozeßkennzahlen erfolgt dabei durch eine kombinierte Kodierung mittels diskreter Berechnung und/oder mittels prozeßspezifischer PCA-Kodierung (Principal Component Analysis). Diskret bedeutet hier das Berechnen einzelner Signalwerte, wie z. B. das Maximum, der steilste Anstieg, deren zeitliches Auftreten etc. Dadurch wird die Signalausprägung sowohl an diskreten Stellen des Signalverlaufes, hauptsächlich jedoch der gesamte Signalverlauf, kodiert durch die PCA-Methode in Form von Prozeßkennzahlen beschrieben. So gewonnene Prozeßkennzahlen unterschiedlicher Signalquellen lassen sich durch nochmalige PCA-Kodierung (hierarchische PCA-Kodierung) ohne wesentlichen Informationsverlust deutlich weiter komprimieren. Aus diesen, mit der PCA erzeugten Kennzahlen kann der ursprüngliche Signalverlauf nahezu identisch rekonstruiert werden. Damit ist also auch eine dateneffiziente Dokumentation der umfangreichen Signalverläufe über einen längeren Fertigungszeitraum realisierbar.

Die Hüllkurven und die PCA-Kodierung werden mit Signaldaten einer Versuchsphase an den jeweiligen Prozeß adaptiert, wodurch eine Trennung in erlaubte und unzulässige Signalformen möglich ist. Dann werden in einer Bewertungsphase die Qualitätsmerkmale den zugehörigen Werten von Prozeßkennzahlen der erzeugten Produkte zugeordnet. Die so auftretenden Prozeßkennzahlen werden neuronalen Netzen oder auch anderen statistischen Prognose-Modellen als dessen Eingangsgrößen zugeordnet. Dann werden die neuronalen Netzwerke derart trainiert, daß sie aufgrund von ungelerten Prozeßkennzahlen die Qualitätsmerkmale für diese Produkte ausreichend genau prognostizieren können in der Form, so daß sie mit hoher Sicherheit dem in einem Produktionszyklus erzeugten Satz von Prozeßkennzahlen Qualitätsmerkmale oder -klassen zuordnen, die möglichst genau mit denen des in diesem Prozeßzyklus erzeugten Produkt übereinstimmen.

In einer Klassifikationsphase werden den erzeugten Prozeßkennzahlen mit Hilfe der trainierten neuronalen Netzwerke Qualitätsmerkmalswerte oder -klassen prognostiziert, die angezeigt und/oder dokumentiert und/oder zum Sortieren der erzeugten Produkte (i.o. oder n.i.o.) und/oder zum Stoppen der Maschine bei zu vielen Schlechteilen dienen.

Bei Überschreiten der zulässigen Qualitätsgrenzen werden weitere neuronale Netze zur Regelung des Prozesses eingesetzt werden, die vergleichbar zu den Qualitätsnetzen gestaltet sind, deren Input/Output-Relation jedoch durch die

Prozeßkennzahlen aus den Signalverläufen und den Einstellwerten der Maschine aus den Versuchsdatensätzen gebildet werden.

Das Training dieser Qualitätsregelnetze mittels der Prozeßkenngrößen und Einstellparameter des Prozesses erfolgt dabei vergleichbar zu den Qualitätsnetzen während der oben beschriebenen Versuchsphase.

Bei den Regeleingriffen wird das Trägheitsverhalten der unterschiedlich schnell ansprechenden Einstellparameter des Prozesses und deren verzögerte Auswirkung auf die Produktqualität berücksichtigt.

Die gesamte Systemstruktur und die Softwarekomponenten sind modular gestaltet. Somit kann durch eine flexible, aufgabenorientierte, effiziente und prozeßspezifische Gestaltung des Systemlayouts eine einfache Systemadaption an unterschiedliche Prozeßkonfigurationen auf einfache Art erfolgen.

Mittels eines Systemteils zur Optimierung bei unzulässiger Produktqualität wird eine neue, bessere Prozeßeinstellung entweder automatisch in dem dem System bekannten Parameterraum oder interaktiv außerhalb davon gefunden.

Eine Besonderheit des erfindungsgemäßen Verfahrens liegt darin, daß neben den adaptiven Hüllkurven zur Prüfung der Signalform unterschiedliche Formen der Signalkodierung und modular gestaltete, neuronale Netze für die Qualitätsprognose und qualitätsbasierte Regelung verwendet werden, die anhand tatsächlich ablaufender Prozeßvorgänge und der dabei in Versuchen ermittelten Werte von Qualitätsmerkmalen trainiert werden, so daß anschließend – nach der Trainingsphase – mit Hilfe dieser Verfahren ohne Prüfung der erzeugten Produkte der Produktionsprozeß so überwacht und geregelt werden kann, daß eine Aussage darüber, ob die Produkte in Ordnung (i.o.) oder nicht in Ordnung (n.i.o.) sind, möglich wird. Die Eingangsparameter des neuronalen Netzes sind Prozeßkennzahlen, die aus Signalverläufen, die von Sensoren im Prozeßablauf gemessen werden, auf unterschiedliche Art ermittelt werden. Der Satz von Prozeßkennzahlen wird dabei derart gewählt, daß er die Information über die Produktqualität enthält.

Eine weiterer, wesentlicher Vorteil des erfindungsgemäßen Verfahrens liegt darin, daß hier neben der klassischen Bestimmung von Kenngrößen eine Signalkodierung (prozeßspezifische PCA) zur Anwendung kommt, die zum einen einen hohen Grad an Datenreduktion erlaubt, dabei jedoch einen maximalen Informationsgehalt zu auftretenden Prozeßschwankungen in den Signalverläufen an die neuronalen Netze überträgt.

Einer nachfolgenden Regelung liegt zugrunde, daß eine Aktivierungslogik eine Abweichung der Qualitätswerte von einem gewünschten Satz von Qualitätswerten feststellt, und bei einer solchen Feststellung mittels der von einem weiteren neuronalen Netzwerk ermittelten Änderungswerte der Einstellgrößen neue Einstellgrößen des Prozesses ermittelt werden. Dabei wird eine weitere Logikstufe aktiv, die prüft, ob langsam veränderliche Einstellparameter bereits den eingeschwungenen Zustand erreicht haben. Erst danach wird im Falle einer prognostizierten, unerlaubten Qualitätsabweichung ein weiterer Regeleingriff veranlaßt.

Bei dieser Weiterbildung des erfindungsgemäßen Verfahrens erfolgt also eine Regelung des Prozesses nur wenn die Produktqualität den erlaubten, wählbaren Bereich verläßt. Dabei laufen sowohl die Überwachung der Signalkurven, die Kodierung, die Überwachung als auch Regelung vollautomatisch ab und es werden nur wenige Produkte, die nicht in Ordnung (n.i.o.) sind, erzeugt. Treten gestörte Signale auf, ist deren Interpretation sehr einfach als Sensordefekt oder unerlaubte Prozeßzustände zu interpretieren.

Die Erfindung wird im folgenden anhand der beigefügten

Zeichnungen näher erläutert. Es zeigen:

Fig. 1 eine schematische Darstellung des Verfahrens;

Fig. 2 die Zusammenhänge der Qualität der erzeugten Produkte mit den verschiedenen Einflußgrößen;

Fig. 3 verschiedene mit Sensoren und dem System gemessene Signalverläufe;

Fig. 4a exemplarische, verschiedene Werkzeuginnendruckverläufe eines Kunststoffspritzgießprozesses für i.o.-Teile;

Fig. 4b exemplarische, verschiedene Werkzeuginnendruckverläufe eines Kunststoffspritzgießprozesses für n.i.o.-Teile;

Fig. 5a eine obere und eine untere Hüllkurve und einen zulässigen Signalverlauf für einen Produktionszyklus des Formnestdrucks eines Kunststoffspritzgießprozesses;

Fig. 5b eine obere und eine untere Hüllkurve und einen unzulässigen Signalverlauf für einen Produktionszyklus des Formnestdrucks eines Kunststoffspritzgießprozesses;

Fig. 5c den prinzipiellen Ansatz zur auf den Signal-schwerpunkt bezogenen Hüllkurvenbestimmung und -überwachung;

Fig. 6 ein Beispiel zu Ausgangssignalen, Datenreduktion und Signalrekonstruktion mittels PCA-Kodierung;

Fig. 7 die prinzipiellen Grundlagen zur Kenngrößenbildung mittels PCA;

Fig. 8 ein neuronales Netzwerk, mit bekannter In-/Outputrelation zur Prozeßüberwachung, das abhängig von den In-/Outputelementen des Netzes automatisch konfiguriert wird;

Fig. 9 eine modulare, merkmalsbezogene Netzanordnung für mehrere, unterschiedliche Qualitätsmerkmale, die hier in der Regel auf Grund der modularen Systemstruktur vorwiegend realisiert und angewandt sind;

Fig. 10a eine Darstellung der funktionalen Gesamtprozeß- und Systemzusammenhänge und die vom System durchzuführenden Aktionen/Reaktionen;

Fig. 10b das Prinzip einer möglichen Gestaltung der neuronalen Netzwerke für die qualitätsbasierte Regelung;

Fig. 11 die prinzipielle, vereinfachte Darstellung der Systemwirkungsweise in einem Parameterraum basierend auf Prozeßeinstellungen;

Fig. 12 die funktionalen Phasen zur Systemadaption an einen Produktionsprozeß;

Fig. 13 ein Prinzip zur Prozeßoptimierung mit der zugrundeliegenden Systementwicklung, mit dem innerhalb des Parameterraumes der Fig. 11 eine automatische, außerhalb davon eine interaktive Optimierung der Prozeßeinstellung erfolgt; und

Fig. 14 die prinzipielle, vereinfachte Darstellung einer Qualitätsfunktion in einem Parameterraum basierend auf Einstellungen von Prozeßparametern.

Fig. 1 zeigt den Ablauf der Überwachung und Regelung eines zyklischen Prozesses, der durch das Rechteck "Prozeß" dargestellt ist. Als exemplarisches Einsatzbeispiel wird im folgenden das Spritzgießen von Kunststoffprodukten betrachtet. Die nachstehend beschriebene Systementwicklung ist jedoch allgemein auf die Überwachung und Regelung zyklisch organisierter Prozesse anwendbar. Beispielfähig sind hier automatisierte Prozesse zu nennen wie Druckgußprozesse, Pulverspritzgießprozesse, Umformprozesse, Schweißprozesse und dabei insbesondere elektrische Schweißprozesse, wie unterschiedliche Formen des Widerstandsschweißens, Punktschweißens, UP-Schweißens etc., Cinchprozesse, Nietprozesse, Lackierprozesse, galvanische Prozesse, beispielsweise zum Beschichten, Siebdruckprozesse, Stanzprozesse, Schneidprozesse und anderes mehr.

Von den dynamischen Abläufen dieser Prozesse, die im folgenden an dem Beispiel Kunststoffspritzgießen erläutert werden, soll sich eine Qualitätsüberwachung ableiten lassen

(Fig. 1), die im unteren Rechteck angezeigt ist, und zwar ohne Untersuchung bzw. Kontrolle des Produktes selbst. Aus dem Ablauf eines Prozesses selbst, der ja kausal verantwortlich dafür ist, ob ein Produkt "in Ordnung" (i.o.) oder "nicht in Ordnung" (n.i.o.) ist, soll abgeleitet werden, ob das hergestellte Erzeugnis i.o. oder n.i.o. ist. Ferner soll im Falle n.i.o. oder deutlich vor Erreichen der Grenze zwischen i.o. und n.i.o. eine Prozeßregelung einsetzen, die also bei einer nicht erlaubten Abweichung des Prozesses von einem bestimmten Soll-Arbeitspunkt die Rückführung auf diesen durch Ableitung von Änderungswerten  $\Delta E_i$  ( $i = 1, 2, \dots$ ) ermöglicht, durch die die Einstellgrößen des Prozesses so korrigiert werden können, daß neue Einstellgrößen  $E_{i, \text{neu}} = E_i + \Delta E_i$  mit  $\Delta E_i = f(Q_k, P_k)$  erzeugt werden, die den Prozeß wieder auf einen optimalen Arbeitspunkt einstellen.

Beispielhafte Signalverläufe des Werkzeuginnendruckes für mehrere Produktionszyklen beim Spritzgießen für die beiden Qualitätsklassen sind in Fig. 4a und 4b dargestellt. In den Fig. 4a und 4b sind wiederum als Beispiel, zwei angußnahe Werkzeuginnendruckverläufe für i.o.-Produkte (Fig. 4a) und für n.i.o.-Produkte (Fig. 4b) dargestellt. Jeweils im rechten oberen Quadranten findet sich dieselbe Darstellung, jedoch nur für die Anfangsphase von wenigen Sekunden, also zeitlich gestreckt. Aus einem Vergleich derselben Werkzeuginnendruckverläufe  $p_F$  (i.o.) in Fig. 4a und  $p_F$  (n.i.o.) in Fig. 4b läßt sich deutlich erkennen, daß typische Charakteristika dieser Druckverläufe mit der Qualität der Teile (i.o. oder n.i.o.) korrelierbar sind. So erkennt man, daß bei den i.o.-Teilen das Maximum der Druckverläufe nach ca. 2,5 bis 3,5 Sekunden erreicht wird, während es bei den n.i.o.-Teilen bei 2,5 bis 5,0 Sekunden auftritt. Man erkennt auch aus den zeitlich gestreckten Abbildungen im rechten oberen Quadranten der beiden Abbildungen, daß der Druckanstieg (Gradient) bei den n.i.o.-Teilen sehr viel stärker in der Steilheit schwankt wie bei den i.o.-Teilen.

Unter Beachtung derartiger Erkenntnisse, die aber in den Fig. 4a und 4b nur beispielhaft zu verstehen sind und die für jeden Prozeß und jede Prozeßkenngröße unterschiedlich sind und daher prozeßspezifisch analysiert werden müssen, kann man aus den Signalverläufen Prozeßkenngrößen  $P_k$  ableiten, und diese mit der Qualität der erzeugten Produkte, also im einfachsten Fall mit der Feststellung i.o. oder n.i.o. für die Teile korrelieren.

Da der Kausalzusammenhang zwischen den einzelnen meßbaren Prozeßsignalen (siehe Fig. 3) – nicht zu verwechseln mit den Einstellgrößen  $E_i$  an der Maschine oder dem Maschinen- und dem Prozeßergebnis, also der Qualität der erzeugten Produkte – so komplex ist, daß eine geschlossene Darstellung – etwa in Form eines analytischen Ausdrucks – nicht möglich ist, muß ohne diese Kenntnis ein Modell dieses Zusammenhangs entwickelt werden, das eine Überwachung der Qualität des erzeugten Produktes und eine daran ausgerichtete Regelung des Prozesses ermöglicht.

Bei vielen Prozessen und ebenso beim Spritzgießen von Kunststoffen hängt die Qualität des Produktes nicht nur von der einstellbaren und eingestellten Funktionen der Maschine und des Werkzeugs, die durch Einzelgrößen  $E_i$  steuerbar sind, ab, sondern auch von den Umgebungsbedingungen und ebenso von den meist unbekannten aktuellen Eigenschaften des Materials, aus dem das Produkt entstehen soll. Diese Zusammenhänge soll Fig. 2 vermitteln.

In einem ersten Schritt sieht das erfindungsgemäße Verfahren die Überwachung der Signalverläufe durch adaptive Hüllkurven für jeden verwendeten Signalverlauf vor. Fig. 5a zeigt ein Hüllkurvenbeispiel mit zulässigem Signalverlauf, Fig. 5b zeigt ein Hüllkurvenbeispiel von einem Produktionszyklus mit unzulässigem Signalverlauf. Durch zwei unterschiedliche Toleranzfunktionen kann ein geringes Über-

und Unterschreiten der oberen und unteren Hüllkurve ermöglicht werden, um auch die Verarbeitung von im Prinzip unzulässigen Signalen in der Nähe des bekannten Arbeitsbereichs des Prozesses zu ermöglichen. Adaptiv bedeutet hier, daß die Hüllkurven aus der oberen und unteren Einhüllenden der maximalen und minimalen Signalwerte jedes erlaubten Signalverlaufes der zugrundeliegenden Versuche automatisch erzeugt werden. Ein Fehler in der Erzeugung der Signale (z.B. Sensor-, Meßverstärker-, Kabeldefekt etc.) oder ein Überschreiten eines gelernten Arbeitsbereichs des Prozesses wird damit sicher erkannt. Ebenso wird eine unzulässige Kodierung unbekannter und somit unerlaubter Systemzustände, mit ungesicherter Qualitätsprognose und falschem Eingriff verhindert.

Eine noch leistungsfähigere Methode der Signalprüfung auf erlaubte Ausprägungen ist in Fig. 5c dargestellt. Während beim oben genannten Verfahren die Toleranzintervalle für jeden Meßpunkt einer Signalkurve unabhängig voneinander bestimmt werden, berücksichtigt diese zweite Methode (Fig. 5c) Korrelationen zwischen den Meßpunkten. Denkt man sich jeden erlaubten Signalverlauf als Punkt in einem Vektorraum dargestellt, so wird ausgehend von der Kovarianzmatrix erlaubter Signalverläufe ein Hüllipsoid konstruiert, das gerade alle erlaubten Prozeßzustände beinhaltet. Mit dieser Konstruktion lassen sich erlaubte Prozeßzustände sehr viel besser von unerlaubten Zuständen trennen.

Der nächste Schritt ist die Ableitung von Prozeßkenngrößen  $P_{ki}$ , die den Prozeßablauf und dessen Schwankungen selbst charakterisieren, die also zwar einerseits von den in Fig. 2 dargestellten Einflußparametern abhängig sind, die sich aber auch bei gleichbleibenden Einstellwerten verändern können.

Fig. 3 zeigt für das Beispiel des Kunststoff-Spritzgießens einige wesentliche Signalverläufe einiger wesentlicher Prozeßgrößen, die während des zu überwachenden Prozesses an einer Spritzgußmaschine auftreten, zwei Triggersignale, den Hydraulikdruck  $p_{Hyd}$ , den Düsendruck  $p_D$ , den Schneckenweg  $s_{Sch}$ , den Druckverlauf  $p_{Fn}$  und  $p_{Pf}$  anguñnah und -fern in einem Formnest, die Düsentemperatur  $T_{DIR}$  und die Werkzeugwand-Temperatur  $T_W$ . Diese Signalverläufe kennzeichnen den realen Ablauf eines Prozeßabschnitts, während ein Produkt, also etwa ein Spritzgußteil, gefertigt wird. Sie werden durch geeignete Sensoren ermittelt. Die Sensorik kann natürlich prozeßabhängig erweitert werden, z. B. um die Schneckenrehzahl, oder aber reduziert werden. Aus diesen Signalverläufen kann mittels bekannter mathematischer Methoden für jeden Signalverlauf eine beliebige Anzahl diskreter Prozeßkenngrößen wie Maximum, Gradient, Integral usw. berechnet werden.

Deutlich leistungsfähiger bezüglich der Kenngrößenbildung ist jedoch die Methode der PCA-Kodierung für die Signalverläufe. Die PCA (Principal Component Analysis) ist eine Methodik der multivarianten Statistik zur Analyse der statistischen Eigenschaften eines multidimensionalen Zufallsvektors. Ausgehend von einer repräsentativen Stichprobe, also einem Satz von Signalverläufen aus Versuchen, ermöglicht die PCA das Auffinden des Unterraumes minimaler Dimension des Musterraumes derart, daß die Projektionen der Muster auf den Unterraum eine vorgebbare Schranke des Rekonstruktionsfehlers nicht überschreiten. Bei Vorgabe eines zulässigen Fehlers von beispielsweise 1% ist es damit in Anwendungen typischerweise möglich, eine Datenkompression von 1 : 100 oder mehr zu erreichen.

Ebenso ist es beim realisierten Ansatz möglich, den Reduktionsfaktor durch Vorgabe der Dimension des Unterraumes festzulegen und den dabei auftretenden Kodierungsfehler bestimmen zu lassen.

Methodisch erfordert die PCA eine Schätzung des Musterschwerpunktes einer Stichprobe und die Lösung des mit der Kovarianzmatrix des Zufallsvektors verbundenen Eigenwertproblems, wobei die Kovarianzmatrix ebenfalls mittels der Stichprobe geschätzt wird. Die algorithmische Implementierung der PCA ist unter Rückgriff auf Standardsoftwarepakete für lineare Probleme möglich. Das vorliegende erfindungsmäßige Verfahren benutzt die PCA zur Ableitung von Prozeßkennzahlen aus den Signalverläufen der zyklischen Meßdatenzeitreihen von den Prozeßzustand erfassenden Sensoren.

In Fig. 6 sind beispielhaft 7 Ausgangssignalverläufe, deren PCA-Kennzahlen und die aus den Kennzahlen rekonstruierten ebenfalls 7 Signalverläufe eines Formnestendruckverlaufes dargestellt. Fig. 7 faßt die wesentlichen Funktionsbausteine und Berechnungsvarianten der PCA zusammen.

Die Ableitung von Prozeßkenngrößen anstelle einer direkten Verarbeitung der Signalverläufe dient dazu, pro Prozeßabschnitt und Meßstelle pro Signalverlauf mit sehr viel weniger Daten und sehr viel weniger Prozessor- und Speicherkapazität auszukommen, wie dies ansonsten erforderlich wäre. Eine solche Ableitung von Prozeßkenngrößen  $P_{ki}$  vor allem mittels der PCA-Methode erlaubt es, die anfallenden Daten so zu reduzieren, daß die anschließende Verarbeitung zur Überwachung und Regelung überhaupt handhabbar wird, und dies bei der PCA-Methode mit minimalem Informationsverlust. Ansonsten würden die Signalverläufe in digitalisierter Form je nach Abtastfrequenz und sonstigen Charakteristika zu einer zu hohen Zahl von zu verarbeitenden Daten führen.

Zur Datenreduktion können also einerseits signifikante Größen der Signalverläufe ermittelt und dargestellt werden, z. B. die Amplitude des Maximums, der Zeitpunkt des Auftretens des Maximums, die Steilheit des Signalverlaufes an bestimmten Stellen, Integrale von Signalsegmenten, usw. Die Ableitung von Prozeßkenngrößen ist in der zusammenfassenden Darstellung nach Fig. 12 jeweils im zweiten Block von links in der zweiten und dritten Reihe zur Bewertung und im dritten Block der Überwachung und Regelung als "Kenngrößen-Berechnung" dargestellt. Beispielsweise kann man für die Überwachung eines Spritzgußprozesses zwischen 20 und 80 Prozeßkenngrößen je nach Prozeßart erhalten.

Ein Merkmal der Erfindung besteht darin, daß die Modellierung des Zusammenhangs zwischen Prozeßkenngrößen  $P_{k1} \dots P_{ki}$  und der Qualität der erzeugten Teile, gegeben durch Qualitätsmerkmale  $Q_m$  und Merkmalsklassen  $Q_{k1} \dots Q_{km}$ , dadurch gekennzeichnet ist, daß ein neuronales Netzwerk  $NN_1$  eingesetzt wird. Ein solches neuronales Netzwerk  $NN_1$  ist in Fig. 8 beispielhaft dargestellt. Im einfachsten Fall bedeutet  $Q_{k1} = i.o.$  und  $Q_{k2} = n.i.o.$  für das überwachte Merkmal. Ein Beispiel kann derart gestaltet sein, daß ein bestimmtes Maß des Produktes etwa zu lang ( $Q_1$ ), zu kurz ( $Q_2$ ) oder zufriedenstellend ( $Q_3$ ) anhand von drei Merkmalsklassen überwacht wird. In einem weiteren Beispiel wird der aktuelle Wert eines Merkmals erforderlich, dazu wird das Netz auf konkrete Werte des Merkmals trainiert. Durch Verwendung mehrerer solcher neuronaler Netzwerke kann das neuronale Netzwerk  $NN_1$  modular für eine beliebige Anzahl von Qualitätsmerkmalen erweitert werden (Fig. 9).

Die Theorie neuronaler Netzwerke ist an sich bekannt. Ein solches neuronales Netzwerk besteht ggf. aus mehreren Schichten, im Beispiel nach Fig. 8 aus drei Schichten, über die eine gewichtete Verknüpfung der Prozeßkenngrößen  $P_{k1} \dots P_{ki}$  mit Qualitätsmerkmalsklassen  $Q_{k1} \dots Q_{km}$ , wie sie für die Qualitätsmerkmale und somit die Qualität ei-

nes erzeugten Produktes charakteristisch sind, hergestellt wird.

In einer ersten "Bewertungs"-Phase (vgl. Fig. 12) werden den aus den Signalverläufen abgeleiteten Prozeßkenngrößen  $Pk_1$  interaktiv bestimmte Qualitätsmerkmale  $Qk_j$  ( $Qk_1 \dots Qk_m$ ) zugeordnet, die durch visuelle Begutachtung und/oder Vermessung der erzeugten Produkte festgestellt werden. Im Beispiel des Spritzgießens kann das z. B. bedeuten, daß bei einem Produkt etwa die Dicke, die Oberflächengüte an verschiedenen Stellen, geometrische Abmessungen und ihre Abweichungen von einem Sollmaß, die Festigkeit, usw. festgestellt werden, die man Qualitätskenngrößen  $Qk_j$  zuordnet. Diese Zuordnung wird nun in einem Trainingsdatenfile erfaßt und dient dann in einem späteren, separaten Vorgang zum "Training" des/der neuronalen Netzwerke(s).

Das Training eines neuronalen Netzwerkes findet anhand des Trainingsdatenfiles, oder eines Teildatensatzes davon, unter Anwendung eines der allgemein bekannten Lernalgorithmen wie z. B. dem Back-Propagation-Algorithmus statt. Fig. 8 zeigt für einen Lernschritt die Änderung der Gewichte im neuronalen Netzwerk NN1 bei Berücksichtigung eines Lernmusters (Fehlersignal wird durch Abweichungen in der Lernphase berechnet und ergibt sich aufgrund der Differenz zwischen Netzausgang und Lernvorgabe).

Durch ein Training, das etwa im Beispiel des Spritzgießens anhand von 60 erfaßten Prozeßabschnitten (d. h. der Erzeugung von 60 Produkten) ablaufen kann, ist es möglich, daß ein neuronales Netzwerk eine Klassifikations- und Prognosesicherheit, d. h. korrekte Zuordnung von Prozeßkenngrößen und Qualitätsmerkmalen, in einer Größenordnung erzielt, die teilweise im Genauigkeitsbereich der üblicherweise eingesetzten Meßmittel zur Überprüfung dieser Prognoseergebnisse liegt.

Auf diese Weise ist es also möglich, durch die Ableitung von Prozeßkenngrößen aus den Signalverläufen von Meßdatenzeitreihen und einem Training des neuronalen Netzwerkes NN1 anhand einer Zuordnung von Qualitätskenngrößen im neuronalen Netzwerk NN1 ein Prozeßmodell zu erstellen, das den kausalen Zusammenhang zwischen den Prozeßkenngrößen  $Pk_i$  und den Qualitätskenngrößen  $Qk_j$  nachbildet und nach Abschluß der Bewertungsphase (Fig. 12) und der Trainingsphase (Fig. 12) anhand der jeweiligen Prozeßkenngrößen eine Aussage erlaubt, ob die Qualität eines Produktes einem bestimmten Satz von Qualitätsprognosewerten entspricht (z. B. i.o. oder 100 mm) oder nicht (z. B. n.i.o. oder 100,9 mm) und zwar ohne Prüfung des Produktes.

Für jedes zur Ermittlung der Qualität herangezogene Qualitätsmerkmal (also etwa: Aussehen der Oberfläche, Füllung der Form, Abmessungen, usw.) kann man auch jeweils ein getrenntes neuronales Netzwerk verwenden, um einen modularen Aufbau und hierarchische Modellstrukturen möglich zu machen.

Wesentlich ist, daß die Kennzahlenbestimmung und die Prognose der Netzwerke jedoch nur mit von der Hüllkurven-Methode erlaubten Signalverläufen erfolgt, und somit eine unerlaubtes Systemergebnis bei unzulässigem Signalverlauf unterbunden wird.

In der Trainingsphase kann z. B. durch hierarchische Anordnung von Netzen zuerst die Überwachung attributiver und dann variabler Merkmale erzeugt werden. In der Trainingsphase des neuronalen Netzwerkes erfolgt somit die attributive oder quantitative Zuordnung bestimmter Qualitätskenngrößen zu Prozeßkenngrößen eines bestimmten Prozeßzyklus oder -abschnitts.

Vor dem Training des neuronalen Netzwerkes kann in einer Datenbank eine Zuordnung der Prozeßkenngrößen zu den Qualitätskenngrößen eines Produktes erfolgen, also die Erzeugung eines Trainingsvektors. Mehrere Trainingsvektoren

ergeben einen Trainingssatz. Die Trainingssätze werden in Trainingsdatenfile gespeichert.

In Fig. 10a ist noch einmal das gesamte System im Zusammenhang dargestellt. Von den Sensoren in der Maschine werden die Sensorsignale abgeleitet. Diese erzeugen dann die entsprechenden Signalverläufe, die an die zentrale Datenverarbeitungseinheit gelangen und dort in der beschriebenen Weise weiterverarbeitet werden.

In Fig. 12 ist der Vorgang der Hüllkurvenbestimmung in der ersten Zeile der Bewertungsphase dargestellt. Die interaktive Bewertung in den nächsten beiden Zeilen erzeugen die Trainingsdatenfile für die Qualitäts- und Reglernetze. Dabei werden die Prozeßkenngrößen abgeleitet und dann den Qualitätsmerkmalen bzw. dem Einstellwerten zugeordnet. In der vierten und fünften Zeile der Fig. 12 ist der Trainingsablauf mit Hilfe der neuronalen Netzwerke NN1 und NN2 dargestellt.

In der sechsten und siebten Zeile der Fig. 12 ist dann die Überwachungs- und Regelungsphase dargestellt, in der nach Abschluß der Trainingsphase direkt aus den Signalverläufen die Qualität prognostiziert wird und eine Sortierung in i.o.-Teile und n.i.o.-Teile bei gleichzeitiger Anzeige und Dokumentation vorgenommen wird. Dabei wird das Netzwerk NN2 nur dann aktiv, wenn vom NN1 ein unerlaubter Qualitätszustand gemeldet wird (Fig. 1).

Das neuronale Netzwerk NN1 (Fig. 8, Fig. 9) sollte so trainiert sein, daß es anhand von Prozeßkennzahlensätzen, symbolisiert durch die Punkte  $P_1, P_2, \dots, P_j$ , in einem Raum arbeitet, vgl. Fig. 11, in dem beispielhaft sowohl die Qualitätsmerkmale für i.o.- und für n.i.o.-Klassen, als auch eine repräsentative Verteilung von variablen Merkmalswerten auftreten, und in dem für Kennzahlenwerte, die nicht während der Trainingsphase erzeugt wurden, ein guter Prognosewert erreicht wird. Man spricht hier von einer Generalisierungsfähigkeit des neuronalen Netzwerkes, wenn für nicht trainierte Kennzahlensätze eine zufriedenstellende Qualitätsprognose erzielt wird.

So soll das Netz nicht nur in der Lage sein, von einem bestimmten eintrainierten Satz von Prozeßkenngrößen z. B. zu einem bestimmten Ergebnis (i.o. oder n.i.o.) zu gelangen. Es sollte auch aus einem Satz Prozeßkenngrößen, zu dem es noch nicht trainiert worden ist und der innerhalb eines definierten i.o./n.i.o.-Bereiches, wie z. B. des Quaders  $P_1 \dots P_8$  in Fig. 11, liegt, ein zuverlässiges Ergebnis liefern.

Ein weiterer Abschnitt des Verfahrens besteht darin, bei prognostizierten n.i.o.-Teilen eine Regelungsfunktion zu aktivieren. Diese soll bei Abweichung der Qualitätskenngrößen  $Qk$  von den erlaubten Werten die Einstellgrößen des Prozesses so verändern, daß die angestrebten Werte der Qualitätsmerkmale erneut erreicht werden.

Dies erfolgt mit Hilfe eines weiteren neuronalen Netzwerkes NN2, das in Fig. 1 und Fig. 12 dargestellt ist. Auch diesem Netzwerk werden die Prozeßkenngrößen  $Pk_1 \dots Pk_i$  eingegeben. Sie werden bestimmten Einstellwerten  $E_{k1} \dots E_{kn}$  zugeordnet, und zwar in einer Trainingsphase derart, daß das Fehlersignal die interne Netzwerkgewichtung der einzelnen Einflußgrößen vergleichbar zum Training der Qualitätsnetze verändert. Am Schluß nach Ablauf der Trainingsphase enthält das neuronale Netzwerk ein Modell, das bei Abweichungen vom Arbeitspunkt des Prozesses (Fig. 11), definiert durch Prozeßkenngrößen  $Pk_i$ , von einem gewünschten Soll-Arbeitspunkt PA Änderungen der Einstellwerte  $\Delta E_{k1} \dots \Delta E_{kn}$  angibt, die eine "Rückführung" des Prozesses auf den aktuell besten Arbeitspunkt PA herbeiführen. Der Weg der Abweichung ist in Fig. 11 als Pfad 1, die Rückführung als Pfad 2 angegeben.

Auch dies erfolgt, dies sei nochmals betont, mit dem wie oben beschriebenen, trainierten Netz ohne jegliche konkrete



Prüfung der erzeugten Produkte. Diese Regelungsphase und deren Konkretisierung ist in Fig. 12 in den Zeilen 3, 5 und 7 dargestellt. Die Beschriftung ist aufgrund der vorstehend gegebenen Erläuterungen selbsterklärend.

Zu den Fig. 1, 10a und 12 ist noch zu ergänzen, daß, bevor eine Änderung der Einstellwerte eingeleitet wird, eine Aktivierungslogik  $f(Qk1 \dots Qkm)$ , die im zweiten neuronalen Netzwerk NN2 vorgesehen ist, vom ersten neuronalen Netzwerk NN1 her aktiviert werden muß. Die Aktivierungslogik kann z. B. – im einfacheren Fall – so ausgelegt sein, daß sie eine Veränderung der Einstellwerte einleitet, wenn ein Produkt n.i.o. ist.

Andererseits sollte die Regelung nicht erst einsetzen, wenn ein Produkt n.i.o. ist. Man möchte die Regelung schon dazu benutzen, bei Veränderungen, die noch innerhalb eines i.o.-Bereiches liegen (also etwa in einem kleineren, im Quader nach Fig. 11 eingeschlossenem Bereich um den Punkt PA) eine Rückführung des Prozesses auf einen optimalen Arbeitspunkt innerhalb des i.o.-Bereiches zu bewirken. Man kann also die Aktivierungslogik auch dann schon ansprechen lassen, wenn ein Auswandern des Arbeitspunktes PA an einen Punkt PA' erfolgt ist, der zwar selbst noch die Herstellung von i.o.-Teilen erlaubt, aber bereits nahe an einem n.i.o.-Bereich liegt.

Fig. 13 ist die Darstellung einer prinzipiellen Lösung einer evolutionsbasierten Regelung bzw. Optimierung. Mit dieser Komponente ist vorgesehen, daß, wenn die Regelung wie beschrieben mit NN2 nicht erfolgreich ist, oder die erfaßten Prozeßkenngrößen  $Pki$  den gelernten Bereich der Hüllkurven (Fig. 5a, 5b, 5c) d. h. den erfaßten Bereich (den Quader in Fig. 11) verlassen, schrittweise die Einstellwerte geändert werden (Fig. 14), und dann die sich dabei ergebenden Qualitätsparameter automatisch festgestellt oder im interaktiven Fall geprüft werden, also untersucht wird, ob sich die Qualitätsmerkmale in Richtung einer Verbesserung oder einer Verschlechterung der Gesamtqualität bewegen oder nicht, und sich so zu einem Punkt "Maximum" bewegen, an dem die Gesamtqualität ein Maximum besitzt, also optimal ist.

Der vom "Start" in Fig. 14 ausgehende Evolutionsverlauf kann dabei auch ergeben, daß eine Veränderung der Einstellparameter die Gesamtqualität nicht verbessert, sondern verschlechtert. Eine Evolutionsstrategie sieht dann vor, daß sich das System, ausgehend von einem vorhergehenden Punkt, eine neue Einstellung in eine andere Richtung sucht, in der wieder eine Verbesserung der Qualität an Hand der Prozeßkennzahlen feststellbar ist.

#### Patentansprüche

1. Verfahren zur Überwachung eines Produktionsprozesses, bei dem Signalverläufe an mehreren Stellen des Produktionsprozesses aufgenommen werden und mindestens eine Qualitätsaussage zu den erzeugten Produkten abgeleitet wird, dadurch gekennzeichnet,

- a) daß die Signalverläufe eines für die Erzeugung der Produkte maßgeblichen Prozeßabschnittes mit Hilfe von Hüllkurven auf ihre Zulässigkeit untersucht werden,
- b) daß aus den zulässigen Signalverläufen des für die Erzeugung der Produkte maßgeblichen Prozeßabschnittes Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) derart ermittelt werden, daß Änderungen der Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) mit Änderungen von Qualitätsmerkmalen ( $Qk1 \dots Qkm$ ) der hergestellten Produkte korrelieren,
- c) daß in einer Bewertungsphase die bei der Erzeugung der Produkte auftretenden Prozeßkenn-

zahlen ( $Pk1 \dots Pkn$ ) den zugehörigen Qualitätsmerkmalen ( $Qk1 \dots Qkm$ ) der erzeugten Produkte zugeordnet werden,

- d) daß die derart gewonnenen Prozeßkennzahlen ( $Pk1 \dots kn$ ) einem neuronalen Netzwerk (NN1) als dessen Eingangsgrößen zugeführt werden,
  - e) daß in einer Trainingsphase das neuronale Netzwerk (NN1) derart trainiert wird, daß es mit hoher Sicherheit den bei einem späteren Prozeßabschnitt erzeugten Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) Qualitätsmerkmale ( $Qk1 \dots Qkm$ ) zuordnet, die gleich denen des in dem Prozeßabschnitt erzeugten Produktes sind, und
  - f) daß in einer Überwachungsphase aus den Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) mit Hilfe des trainierten neuronalen Netzwerks (NN1) Qualitätsmerkmalswerte und -klassen abgeleitet werden, die angezeigt und/oder dokumentiert und/oder zum Sortieren der erzeugten Produkte (i.o. oder n.i.o.) und/oder zur Regelung des Produktionsprozesses eingesetzt werden.
2. Verfahren nach Anspruch 1, dadurch gekennzeichnet, daß die Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) entweder durch eine diskrete Berechnung oder durch eine PCA-Kodierung (PCA = Principal Component Analysis) oder durch eine Kombination davon ermittelt werden.
3. Verfahren nach Anspruch 1 oder Anspruch 2, dadurch gekennzeichnet, daß die Hüllkurven und/oder die PCA-Kodierungen mit Hilfe von Signalverläufen einer Versuchsphase an den Produktionsprozeß angepaßt werden, wobei in der Versuchsphase die Einstellungen des Produktionsprozesses gezielt verändert werden.
4. Verfahren nach einem der vorstehenden Ansprüche, dadurch gekennzeichnet,
- g) daß die Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) einem weiteren neuronalen Netzwerk (NN2) als Eingangsgrößen zugeführt werden,
  - h) daß in einer Bewertungsphase den im Versuch erzeugten Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) die dazugehörenden, variierten Einstellgrößen ( $Ei$ ) des Produktionsprozesses zugeordnet werden,
  - i) daß das weitere Netzwerk (NN2) in einer Trainingsphase trainiert wird,
  - j) daß eine Aktivierungslogik eine Abweichung der Qualitätsmerkmale ( $Qk1 \dots Qkm$ ) von gewünschten Qualitätsmerkmalen feststellt, und
  - k) daß dann mittels der durch das weitere Netzwerk (NN2) ermittelten Änderungswerte ( $\Delta Ei$ ) der Einstellgrößen ( $Ei$ ) neue Einstellgrößen ( $Ei$ , neu) des Produktionsprozesses erzeugt werden.
5. Verfahren nach Anspruch 4, dadurch gekennzeichnet,
- l) daß die Einstellgrößen ( $Ei$ ) geändert und die sich ergebenden Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) festgestellt werden,
  - m) daß geprüft wird, ob sich die Qualitätsmerkmale ( $Qk1 \dots Qkm$ ) in Richtung einer Verbesserung der Qualität bewegt, und
  - n) daß, falls dies zutrifft, der Produktionsprozeß mit den neuen Prozeßkennzahlen ( $Pk1 \dots Pkn$ ) als Arbeitspunkt (PA) fortgesetzt wird.
6. Verfahren nach Anspruch 5, dadurch gekennzeichnet,
- o) daß, falls dies nicht zutrifft, ein vorhergehender Arbeitspunkt gewählt wird und die Einstellgrößen ( $Ei$ ) mittels einer Optimierungsstrategie in eine andere Richtung geändert werden.

7. Verfahren nach einem der vorstehenden Ansprüche, dadurch gekennzeichnet, daß das Trägheitsverhalten der Einstellparameter (Ei) des Produktionsprozesses im Hinblick auf seine Auswirkung auf die Qualität der erzeugten Produkte berücksichtigt wird.

5

8. Verfahren nach einem der vorstehenden Ansprüche, dadurch gekennzeichnet, daß die einzelnen Schritte des Verfahrens als modulartige Softwarekomponenten ausgebildet werden.

10

Hierzu 13 Seite(n) Zeichnungen

15

20

25

30

35

40

45

50

55

60

65



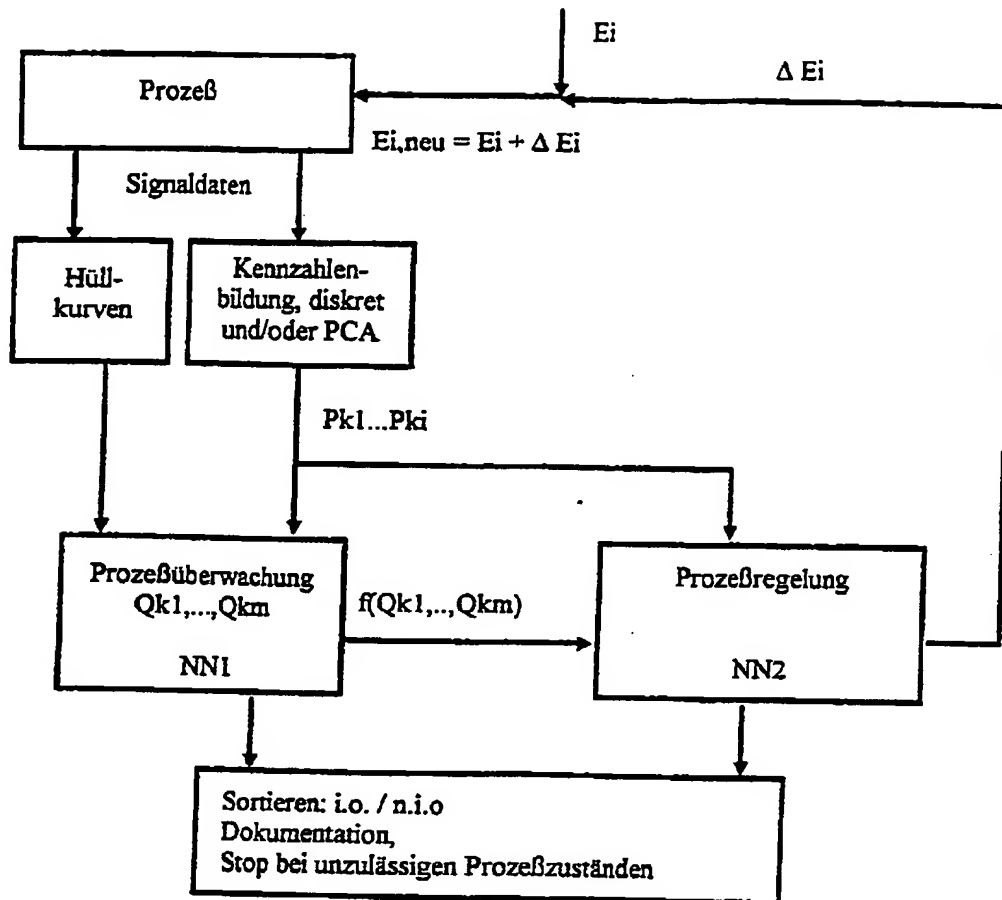


Fig. 1

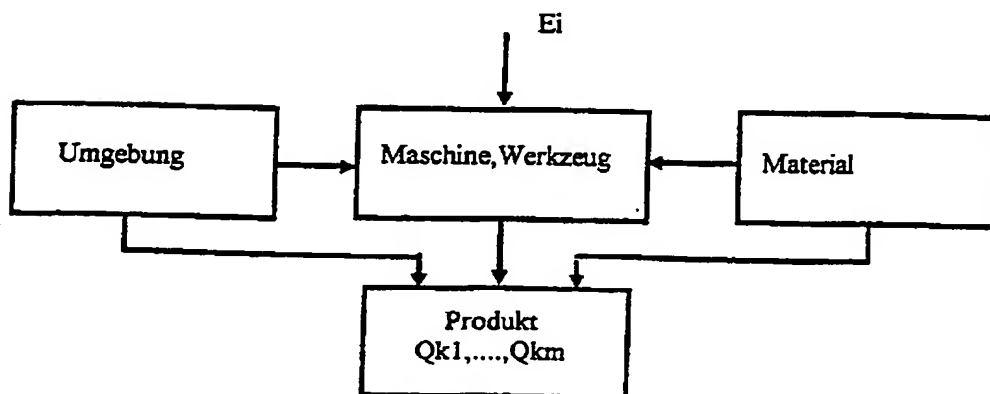


Fig. 2




Fig. 3




Fig. 4a




Fig. 4b




Fig. 5a




Fig. 5b




Fig. 5c





Fig. 6



Funktionsbausteine :    Schwerpunktsvektor  
                                 Kovarianzmatrix  
                                 Eigenvektoren mit Eigenwerten  
                                 Signalkodierung d.h. Prozeßkennzahlen-Bildung  
                                 Signalrekonstruktion zur Visualisierung

Berechnungsvarianten: a) Kovarianz-Matrix (dim  $N \cdot N$ )  
                                 b) Singular Value Decomposition SVD (dim  $N \cdot n$ )  
                                 c) Gram'sche Matrix (dim  $n \cdot n$ )  
                                 mit     $N$ : dimension der Mustervektoren  
                                         $n$ : Stichprobenumfang der Muster

exemplarischer Ansatz: bei z.B.  $n=50$  Versuchen und  $N=4000$   
                                 Signalstützstellen d.h.  $n \leq N$   
                                 ist Variante c) zu favorisieren

Ziel:                        Transformation von korreliertem Vektorraum (dim.  $N$ ) in  
                                 unkorrelierten Raum (dim  $m \leq n$ )

Fig. 7



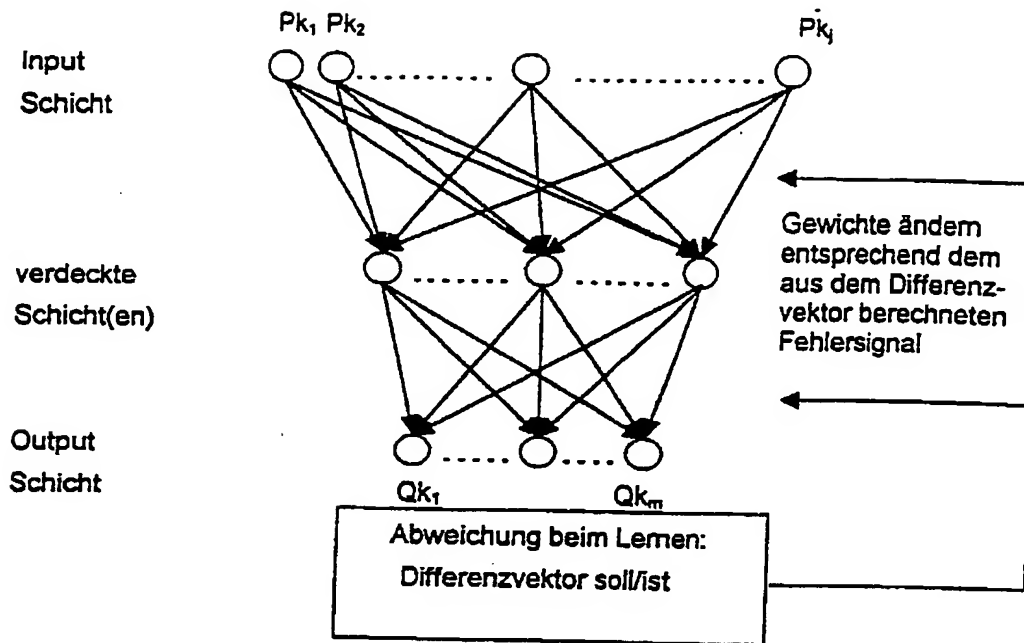


Fig. 8




Fig. 9

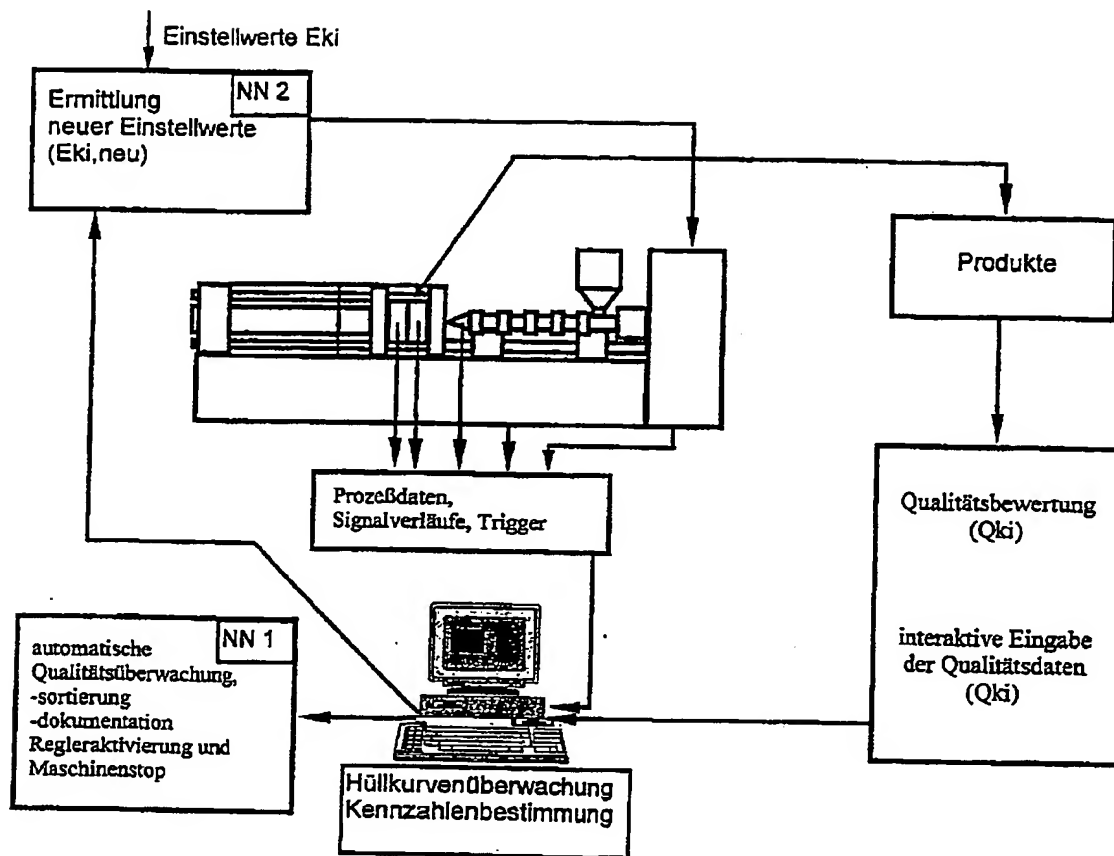


Fig. 10a

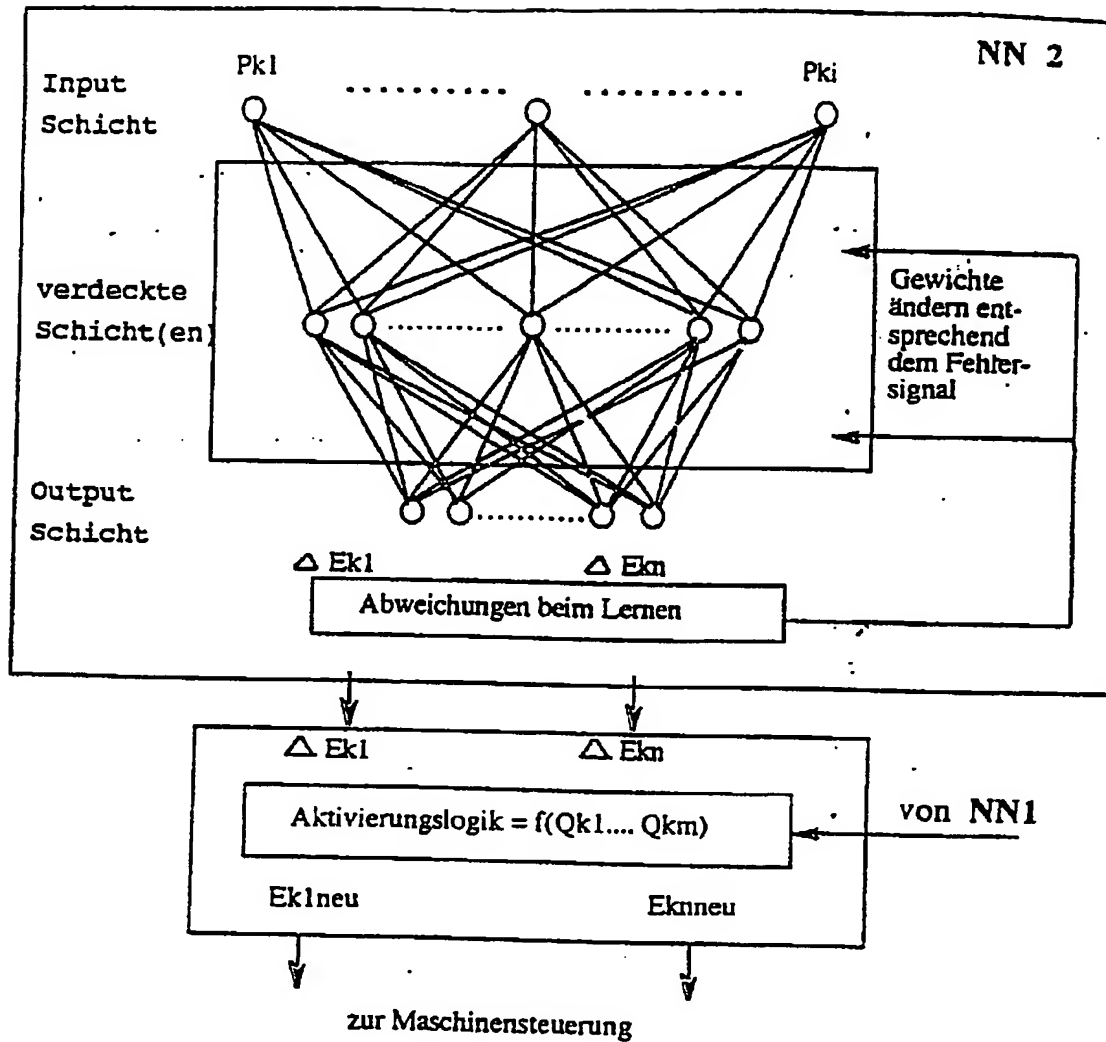


Fig. 10b




Fig. 11

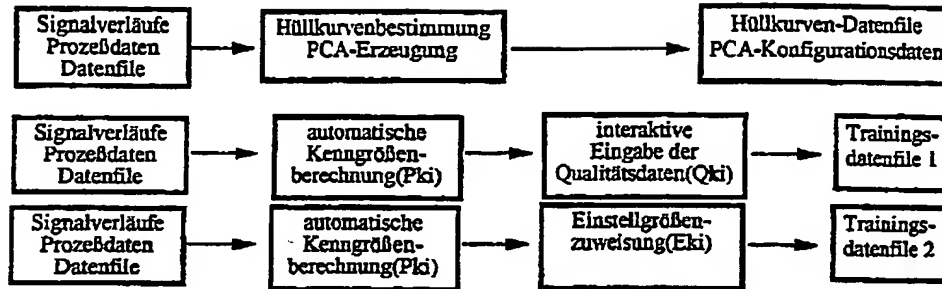


**Bewertungsphase:****Trainingsphase:****Überwachung:****Regelung:**

Fig. 12




Fig. 13






Fig. 14